

**SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI**

Borna Kapusta

**SIMULACIJA PRIORITETA PROLASKA VOZILA ŽURNE
SLUŽBE KROZ SEMAFORIZIRANO RASKRIŽJE**

ZAVRŠNI RAD

Zagreb, 2017.

Umjesto ove stranice uvezuje se zadatak diplomskog rada...

Obrazac ZADATAK ZAVRŠNOG RADA uvezuje se kao prva stranica završnog rada
ispred potkorice.

Sveučilište u Zagrebu
Fakultet prometnih znanosti

ZAVRŠNI RAD

**SIMULACIJA PRIORITETA PROLASKA VOZILA ŽURNE
SLUŽBE KROZ SEMAFORIZIRANO RASKRIŽJE**

**SIMULATION OF PREEMPTIVE TRAFFIC LIGHT CONTROL
FOR EMERGENCY VEHICLES**

Mentor: doc. dr. sc. Edouard Ivanjko

Student: Borna Kapusta
JMBAG: 0135233675

Zagreb, rujan 2017.

Zahvale

Zahvaljujem se svojem mentoru doc. dr. sc. Edouardu Ivanjku na brojnim savjetima, smjernicama i riječima podrške prilikom pisanja ovog rada. Zahvaljujem se dr. sc. Miroslavu Vujiću na savjetima i danim materijalima. Zahvaljujem se kolegi Mladenu Miletiću na pomoći, podršci, te inspiracijom tijekom studiranja i pisanja ovog rada. Također se zahvaljujem svojoj obitelji i prijateljima na potpori te strpljenju tijekom mog studiranja.

Sažetak

Naslov: Simulacija prioriteta prolaska vozila žurne službe kroz semaforizirano raskrižje

Zbog sve veće prometne potražnje i razvoja društva, u urbanim sredinama broj vozila sve više raste, ali se prometna infrastruktura ne mijenja značajno. Utjecajem urbane okoline i ograničenja, često više nije moguće širiti prometnu infrastrukturu. Zbog takvih uvjeta dolazi do sve više prometnih zagušenja i nesreća. Budući da se infrastruktura fizički više ne može širiti, jedino preostaje učiniti ju pametnijom, odnosno nadograditi ju rješenjima koje nam donose Inteligentno Transportni Sustavi (ITS). Implementacija rješenja iz područja ITS-a za upravljanje semaforiziranim raskrižjem u urbanim sredinama korisnicima pruža osim rasterećenja prometa i informiranja putnika, dodatne mogućnosti poput dodjele prioriteta vozilima žurnih službi. U ovom radu je predložen i implementiran algoritam dodjele prioriteta zasnovan na praćenju položaja vozila i mjerenju duljine reda čekanja na raskrižju. Algoritam korištenjem procjene vremena dolaska žurnog vozila čisti raskrižje od vozila te osigurava bezuvjetni prioritet prolaska žurne službe kroz raskrižje. Nakon prolaska žurne službe kroz raskrižje, predložen je i implementiran algoritam za povratak oduzetog vremena kako bi se smanjio negativan utjecaj na prometnu mrežu zbog dodjele prioriteta vozilu žurne službe. Navedeni algoritmi su implementirani u programskom paketu MATLAB povezan COM sučeljem s mikroskopskim simulatorom PTV VISSIM radi njihove simulacijske provjere.

Ključne riječi: Inteligentni transportni sustavi, Simulacije u prometu, Urbana raskrižja, Dodjela prioriteta.

Abstract

Title: Simulation of Preemptive Traffic Light Control for Emergency Vehicles

Due to increasing traffic demand and the development of society, the number of vehicles in urban areas is growing, but transport infrastructure does not change significantly. By the influence of the urban environment and constraints, it is often not possible to expand the transport infrastructure. Due to such conditions, there are increasing traffic congestion and accidents. As the physical infrastructure cannot longer expand, the only thing left is to make it smarter and upgrade it with solutions that are brought by Intelligent Transport Systems (ITS). Implementation of services from the ITS area for traffic light control in urban environments not only provides users with the added convenience of delivering better traffic demand and information to passengers yet provides priority assignment to emergency services vehicles also. In this thesis, an algorithm for preemptive traffic control has been proposed and implemented based on vehicle position tracking and metering at the intersection. The algorithm uses the estimated arrival time of the emergency vehicle to clear the intersection from vehicles and ensures absolute passing priority through the intersection for the emergency service vehicle. After emergency vehicle passes through the intersection, an algorithm for returning withdrawn time has been proposed and implemented to reduce the negative impact on the traffic network by prioritizing the emergency service vehicle. Mentioned algorithms have been implemented in MATLAB that is linked using the COM interface with the microscopic simulator PTV VISSIM for their simulation testing.

Keywords: Intelligent transport systems, Traffic simulations, Urban intersections, Preemptive traffic light control.

Sadržaj

| | | |
|----------|--|-----------|
| 1 | Uvod | 1 |
| 2 | Upravljanje prioritetima prolaska vozila žurnih službi | 4 |
| 2.1 | Strategije dodjeljivanja prioriteta na semaforiziranim raskrižjima | 5 |
| 2.1.1 | Pasivne strategije dodjele prioriteta | 6 |
| 2.1.2 | Aktivne strategije dodjele prioriteta | 8 |
| 2.1.3 | Prometno adaptivne strategije dodjele prioriteta | 11 |
| 2.2 | Algoritam za dodjelu prioriteta zasnovan na duljini reda čekanja i praćenju vozila | 12 |
| 2.2.1 | Algoritam za dodjelu prioriteta | 13 |
| 2.2.2 | Algoritam vraćanja oduzetog vremena | 15 |
| 3 | NEMA struktura signalnih planova | 17 |
| 4 | Simulacijsko okruženje PTV | |
| | VISSIM/MATLAB | 19 |
| 4.1 | Simulacijski alat PTV VISSIM | 19 |
| 4.2 | Programski paket MATLAB | 22 |
| 4.3 | Povezivanje MATLAB-a i VISSIM-a pomoću COM sučelja | 24 |
| 5 | Generiranje i praćenje vozila žurnih službi u PTV VISSIM-u | 27 |
| 5.1 | Postavljanje vozila u mrežu | 27 |
| 5.2 | Praćenje položaja vozila žurnih službi | 29 |
| 6 | Rezultati simulacije | 31 |
| 6.1 | Prometni model i podaci | 31 |
| 6.2 | Postavke simulacije i rute vozila | 32 |

| | | |
|-----|---|-----------|
| 6.3 | Analiza dobivenog vremena putovanja | 34 |
| 7 | Zaključak | 40 |
| | Literatura | 43 |
| | Popis slika | 44 |
| | Popis tablica | 45 |
| | Popis grafikona | 46 |

1 Uvod

Nagli razvoj motornog prometa doveo je do eksponencijalno rastućeg broja prometnih entiteta na prometnicama. Sve veći broj vozila uzrokovao je negativne posljedice kao što su smanjenje sigurnosti u prometu i zagušenje prometa. Uslijed toga sve više se pažnje pridavalo pravilima i propisima za ponašanje sudionika u prometu, pa tako i potrebi za uvođenjem uređaja za regulaciju prometa.

Promet je oduvijek bio bitan čimbenik razvoja i funkcionalnosti ljudskog društva, djelujući na ekonomiju, gospodarstvo, zdravstvo i sve ostale bitne čimbenike za razvoj društva. Promet je izrazito složen tehnički, tehnološki, organizacijski, društveni organizam i nije ga moguće sagledati kao sustav s kojim se može jednostavno upravljati. Zbog sve veće prometne potražnje i razvoja društva, širi se i prometna infrastruktura. U urbanim sredinama broj vozila sve više raste, ali je prometna infrastruktura ograničena za proširenja. Zbog urbane okoline i pripadnih ograničenja, često više nije moguće širiti infrastrukturu. Zbog takvih uvjeta dolazi do sve više prometnih zagušenja i nesreća. Za uspješno rješavanje zagušenja prometnice je potrebno napraviti pametnijima, što donose inteligentni transportni sustavi (ITS). ITS omogućuje informacijsku transparentnost, upravljivost i poboljšan odziv prometnog sustava čime on poprima attribute inteligentnoga. U [1] se može naći sljedeća definicija ITS-a: "ITS se definira kao holistička, upravljačka i informacijsko-komunikacijska (kibernetika) nadogradnja klasičnog sustava prometa i transporta kojim se postiže znatno poboljšanje performansi, odvijanje prometa, učinkovitiji transport putnika i roba, poboljšanje sigurnosti u prometu, udobnost i zaštita putnika, manja onečišćenja okoliša, itd." [1], [2].

Središnji prometni upravljački sustav prikuplja informacije s prometnica, semaforiziranih raskrižja, adaptivno upravlja semaforiziranim raskrižjima, šalje odgovarajuće informacije o stanju na cestama vozačima cestovnih vozila itd. Prometne informacije kao što su broj vozila dostupni na dijelu prometnice, mjesto i vrijeme nastanka nesreće, vremenske uvjete i slično, uvelike mogu pomoći pri boljem reguliranju prometa i boljom

sigurnošću na prometnicama. Osim adaptivnog upravljanja prometnicama koje pridonose optimizaciji prometnih tokova i sigurnosti, sustav može i služiti kao automatizirani nadzor prekršitelja prometne regulative, upravljanje potražnjom, upravljanje u području javnog gradskog prijevoza, informiranja putnika i sl. Zagušenja prometa, osobito u vršnim satima ne utječe samo na promet osobnih automobila i javnog gradskog prijevoza (JGP) već i na dolazak žurnih službi na potrebno mjesto. Takva zagušenja ugrožavaju živote unesrećenih i sigurnost sudionika u prometu. Iako žurne službe imaju pravo prolaska kroz crveno svjetlo na semaforu, gubi se velika količina vremena na raščišćavanje vozila pred raskrižjem, te je znatno smanjena sigurnost. Smanjenje vremena odziva žurnih službi bitno utječe na smanjenje smrtno stradalih i sprječavanje dodatno stradalih nakon prometne nesreće pa je od iznimne važnosti osigurati što brži prolazak vozila žurnih službi kroz urbanu cestovnu prometnu mrežu. Sustavi dodjele prioriteta žurnim službama mogu uvelike smanjiti njihova kašnjenja te povećati sigurnost svih sudionika u prometu na ruti vozila žurne službe. Poznavanjem rute vozila i stanja na prometnicama, moguće je napraviti adaptivni sustav upravljanja signalnim planovima i to na nekoliko raskrižja unaprijed te time omogućiti informiranje vozača o dolasku žurnog vozila, smanjiti broj vozila na ruti žurnog vozila, te u konačnici omogućiti siguran i brz prolaz kroz semaforizirano raskrižje bez zaustavljanja [3].

Cilj ovog rada je predstaviti problematiku dodjele prioriteta na semaforiziranim raskrižjima, napraviti simulacijsko okruženje korištenjem programskog paketa MATLAB i mikrosimulacijskog alata VISSIM, te implementirati i evaluirati algoritam dodjele prioriteta vozilima žurnih službi. Algoritam korištenjem procjene vremena dolaska žurnog vozila i reda čekanja na privozu raskrižja, mijenja trajanje faza signalnog plana s ciljem omogućavanja neometanog bezuvjetnog prolaska vozila žurne službe kroz raskrižje. Predložen je i implementiran algoritam za povratak oduzetog vremena kako bi se smanjio negativan utjecaj na prometnu mrežu zbog dodjele prioriteta vozilu žurne službe. Algoritam je implementiran za slučaj izoliranog semaforiziranog raskrižja korištenjem navedenog simulacijskog alata PTV VISSIM i programskog paketa MATLAB.

Rad je podijeljen u sedam poglavlja. U uvodnom poglavlju je iznesena motivacija, cilj i osnovna struktura rada. Drugo poglavlje opisuje problematiku i tehnike upravljanja

prioritetom prolaska vozila žurnih službi, te objašnjava predloženog algoritma dodjele prioriteta i algoritma vraćanja oduzetog vremena, zasnovanih na praćenju lokacije vozila i duljini reda čekanja. U trećem poglavlju opisuje se NEMA struktura signalnih planova. U četvrtom poglavlju opisano je simulacijsko okruženje i korišteni programski alati. U šestom poglavlju je opisan prometni model i postavke simulacije, prometni scenariji korišteni u simulacijama, te je dan prikaz i analiza dobivenih rezultata. U zadnjem poglavlju dan je zaključak prema prethodnim poglavljima.

2 Upravljanje prioritetima prolaska vozila žurnih službi

Semaforizirana raskrižja igraju glavnu ulogu u sigurnosti i efikasnosti kretanja vozila i pješaka u urbanom prometu. Cilj signalnog plana na semaforiziranom raskrižju je koordinirati prometne entitete bilo koje skupine tako da se kreću što efikasnije i sigurnije. Takvim strategijama postiže se minimalno vrijeme putovanja, vrijeme čekanja, te se smanjuje mogućnosti stvaranja konflikata, odnosno prometnih nesreća. Signalni planovi se pretežito izrađuju i implementiraju na individualno raskrižje bez mogućnosti za široku primjenu na ostala raskrižja. Upravljanje prometom mora biti postavljeno i implementirano na razini cijelog sustava.

Dodjela prioriteta pretežito je naglašena u razvoju i optimizaciji javnog gradskog prijevoza zbog sve većih zagušenja u urbanim sredinama. Takve tehnike i strategije se mogu primijeniti i za vozila žurnih službi. Iznenadni nenajavljeni dolazak žurnih službi na raskrižje na putu do hitnog slučaja može biti jako dezorijentirajuće za ostale sudionike u prometu kako bi se na vrijeme i sigurno maknuli s puta. Često rezultira konfliktima s drugim sudionicima u prometu, žurnom službom ili blokiranjem i zagušenjem prometnih tokova [4].

Prema detaljnoj i opsežnoj analizi ureda za promet države Oregon, SAD (engl. State of Oregon, Office of Transportation) ustanovilo se da 31% do 39% ukupnog putovanja vozila JGP-a otpada na samu vožnju, dok ostatak vremena potroši na čekanje na stajalištima, raskrižjima te zastojima u prometu. Prema toj analizi 27% ukupnog vremena putovanja uključuje čekanje na semaforiziranim raskrižjima [5]. Taj je postotak moguće smanjiti odgovarajućim upravljanjem semaforiziranim raskrižjem.

2.1 Strategije dodjeljivanja prioriteta na semaforiziranim raskrižjima

Dodjeljivanje prioriteta je upravljačka metoda koja omogućava brže kretanje vozila poput žurnih službi i JGP-a prilagođavanjem signalnih planova. Dodjeljivanje prioriteta na semaforiziranim raskrižjima je mjera ITS-a koja modificira ustaljeni proces prometne signalizacije radi boljeg odvijanja prometa za ciljanu skupinu prometnih entiteta. Cilj je smanjiti vrijeme čekanja i vrijeme putovanja, te povećati kvalitetu usluge s minimalnim utjecajem na ostali promet. Adaptivno upravljanje prometom je testirano i implementirano diljem svijeta, posebice u Europi i Sjedinjenim Američkim Državama. Mnoga istraživanja kao što navodi [6], pokazala su da utjecaji i efektivnost strategija upravljanja dodjeljivanjem prioriteta dosta ovisi o prometu u okolici. Stoga, kako bi se odabrala idealna strategija potrebno je analizirati kako određena strategija utječe na određenu prometnu okolinu [6].

Strategije dodjeljivanja prioriteta su implementirane i testirane na prometnoj infrastrukturi ili u računalnoj simulaciji u posljednjih 20 ili 30 godina. Zahvaljujući tim istraživanjima i testiranjima postoje mnogobrojne recenzije i evaluacije strategija u različitim promjenama uvjetima. Strategije dodjeljivanja prioriteta na semaforiziranim raskrižjima mogu se podijeliti na tri osnovna pristupa [7], [5]:

- **Aktivni i pasivni prioriteti** - aktivni prioriteti se odnose na detekciju pristupa vozila žurne službe u stvarnom vremenu, dok se pasivni prioriteti odnose na prethodno izmjerenim prometnim veličinama i uključuju predefiniranu koordinaciju signalnog plana;
- **Potpuni, djelomični i relativni prioriteti** - Prema [7], strategije dodjeljivanja apsolutnog, djelomičnog i relativnog prioriteta mogu se opisati:
 - **Apsolutni prioritet** - strategija koja daje potpuni prioritet i zelenu fazu bez čekanja. Nastoji vozilu žurne službe dati pravo prolaska raskrižju bez odgode;
 - **Djelomični prioritet** - djelomično davanje prioriteta dopušta strategiju s najma-

- nje utjecaja na ostali promet, poput produživanje zelene faze i skraćivanje faze crvenog svijetla s ciljem ranijeg početka faze zelenog svijetla;
- **Relativni prioritet** - pod relativnim prioritetom vozilo kojem je potrebna dodjela prioriteta, uspoređuje s ostalim prometom za dodjelu prioriteta i faze zelenog svijetla. Jedan od značajki odnosno bitnosti zahtjeva je broj putnika, ali zahtjev može biti odbijen zbog prometnog volumena i reda duljine čekanja na ostalim prilazima.
 - **Uvjetni i bezuvjetni prioriteti** - Pristup koji se uglavnom odnosi na vozila JGP-a. Bezuvjetni prioritet je ako se vozilu JGP-a dodjeli prioritet, bez obzira na kašnjenje za voznim redom ili mali broj putnika. Tehnike uvjetnog prioriteta koriste uključivanje dodjelu prioriteta samo ako vozilo ispunjava definirane uvjete poput kašnjenja za voznim redom, promjena linije itd.

2.1.1 Pasivne strategije dodjele prioriteta


Pasivne strategije koriste prethodno obavljene analize i mjerenja relevantnih prometnih veličina prometnog toka, te zahtjeva sustav vozila koji traži dodjeljivanje prioriteta kao ulazne parametre za izmjenu signalnog plana. Strategija pasivne dodjele prioriteta ne zahtjeva sustav nadgledanja, kao ni sustav detekcije i praćenja vozila. Ne obrađuje i ne koristi trenutne mjerne podatke s prometnice, odnosno promjene prometnog toka. Cilj pasivne strategije je smanjiti vrijeme čekanja vozila na semaforiziranom raskrižju smanjenjem trajanja ciklusa ili izmjenom redoslijeda pojedinih faza da bi se omogućilo što veća učestalost zelenog svjetla [5].

Podešavanje duljine ciklusa signalnog plana

Tehnika produljenja faze zelenog svijetla uključuje detekciju odabranog vozila, dodjelu prioriteta, te produljenje faze zelenog svijetla dok vozilo žurne službe ne prođe. Produljenje faze zelenog svijetla može se svrstati u dvije vrste: produljenje zelenog svijetla, te skraćivanje trajanja crvenog svjetla. Na osnovu predviđenog dolaska vozila na raskrižje, faze se modificiraju tako da se dodjeli zeleno svjetlo odabranom vozilu [5].

Razdvajanje faza

Tehnika razdvajanje faza dijeli trenutnu signalnu fazu na privozu vozila kojem je potrebna dodjela prioriteta u više faza s duljinom jednakom originalnom trajanju. Tehnika razdvajanja faza se koristi kod raskrižja kod kojih je striktno napravljen signalni plan i ne smije se mijenjati trajanje pojedinih faza kako se ne bi utjecalo na protok ostalog prometa [5].




Slika 1: Grafički prikaz pasivne tehnike razdvajanja faze [5]

Koordinacija voznog reda

Tehnika dodjele prioriteta pomoću koordinacije, uglavnom se odnosi na vozila JGP-a. Ova tehnika je osnovana na rasporedu dolaska JGP-a. Signalni plan se koordinira po voznom redu JGP-a, poput zelenog vala. Ne mora se odnositi samo na jednu prometnicu, ali se ne koristi zbog velikih odstupanja posluživanja, odnosno vremena potrebnog da se putnici iskrcaju i ukrcaju u vozilo JGP-a na stajalištima [5].

Smanjenje trajanja ciklusa

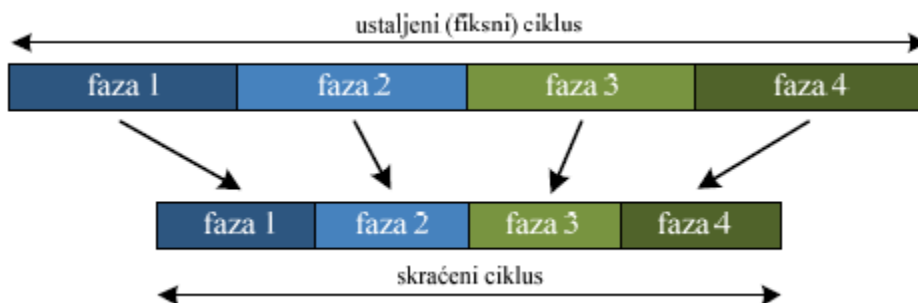
U tehnici smanjenja trajanja ciklusa cilj je povećanje frekvencije uključivanja zelenog svjetla pomoću smanjenja trajanja svih faza u signalnom planu. Većom frekvencijom uključivanja zelenog svjetla vozilima kojima je potreban prolaz kroz raskrižje omogućavamo brži prolaz kroz raskrižje, ali ako nema odabranih vozila nema ni negativnih efekta. Vrijeme trajanja faza se ravnomjerno smanjuje u ciklusu relativnom udjelu pojedine faze [5].



Slika 2: Grafički prikaz pasivne tehnike razdvajanja faze [5]

“Preskakanje” reda čekanja

Tehnika preskakivanja reda čekanja može se koristiti i idealna je za raskrižja s infrastrukturu koja omogućava vozilima JGP-a i vozilima žurnih službi poseban trak za brži prolaz kroz raskrižje. Ova tehnika omogućava dodatnoj prometnoj traci dodatno zeleno svjetlo (ranije zeleno svjetlo) da bi odabrana vozila brže prošla kroz raskrižje [5].



Slika 3: Grafički prikaz pasivne tehnike smanjenja trajanja ciklusa [5]

2.1.2 Aktivne strategije dodjele prioriteta

Strategija aktivne dodjele prioriteta zahtjeva mogućnost obrade mjernih podataka s osjetila na prometnicama, odnosno raskrižjima u stvarnom vremenu. Kako bi se takva strategija implementirala potrebni su mjerni podaci u stvarnom vremenu za sustav detekcije i identifikacije ciljane skupine vozila kojima je potrebna dodjela prioriteta. Takvim sustavima omogućena je izmjena signalnog plana u svrhu što manjeg čekanja ciljane skupine vozila na prolazak raskrižjem. Kao takve, ove strategije su zbog preciznosti i učinkovitosti trenutno najčešće korištene strategije upravljanja semaforiziranim raskrižjima. Mogu se dijeliti na sljedeće četiri skupine aktivnih tehnika [5]:

1. Produljenje trajanja zelenog svjetla;
2. Skraćivanje crvenog svjetla, odnosno raniji početak zelenog svjetla;
3. Dodatna faza za ciljanu skupinu vozila;
4. Selektivne strategije.

Produljenje trajanja zelenog svjetla


Kako bi se smanjilo čekanje određene skupine vozila na semaforiziranom raskrižju, ili ga u potpunosti maknulo, koristi se tehnika produljenja trajanja zelenog svjetla. Tehnika produljenja trajanja zelenog svjetla na dolazak odabrane skupine vozila produljuje fazu zelenog svjetla sve dok vozilo ne prođe raskrižje ili ne istekne najduže vrijeme produljenja faze. Ako se ne radi o žurnim službama, maksimalna vrijednost trajanja zelenog svjetla mora se definirati zbog utjecaja na protok vozila na ostalim privozima raskrižja i mogućnosti višestrukih zahtjeva za prioritetom [5].

Tehnika produljenja trajanja zelenog svjetla uglavnom se koristi na raskrižjima sa samo dvije faze. Također maksimalno produljenje zelenog svjetla ima ograničenja zbog utjecaja na ostatak prometa. Najduže vrijeme produljenja vremena faze zelenog svjetla se mijenja ovisno o prometnom opterećenju, broju vozila kojima je potrebno adaptivno upravljanje itd. U većini slučajeva koriste se granice u vremenskom okviru od 10 do 20 sekundi ili relativno produljenje trajanja faze do 20 % [6]. Relativno produljenje trajanje faze je korišteno u ovom radu s najvećim dopuštenim iznosom od 20 %. Kada je riječ o vozilima žurne službe i opasnosti po život, faza zelenog svjetla se produljuje sve dok vozilo ne prođe raskrižjem.

Kako bi se detektirao dolazak i prolazak odabranog vozila kroz raskrižje, potrebna su dva detektora. Jedan prije raskrižja kako bi sustav znao da vozilo dolazi i traži prioritet, te jedan nakon raskrižja kako bi sustav znao da je vozilo prošlo kroz raskrižje. U novije vrijeme koriste se tehnologije poput GPS-a, kod kojeg nisu potrebni detektori na infrastrukturi, već samo uređaj u vozilu koji koordinate vozila na prometnici javlja upravljačkom sustavu raskrižja [5].

Skraćivanje crvenog svjetla, odnosno raniji početak zelenog svjetla


Ovom tehnikom se skraćuje trajanje faze crvenog svjetla ukoliko odabrana skupina vozila prilazi raskrižju, a predviđen je dolazak za vrijeme trajanja crvenog svjetla. Ova tehnika se koristi kako bi se skratilo vrijeme čekanja odabrane skupine vozila, te ranije uključilo zeleno svjetlo na tom privozu. Ukoliko je po signalnom programu definirano više faza na raskrižju, moguće je skratiti sve ili samo neke faze. Isto kao i kod tehnike produljenja trajanja zelenog svjetla, tehnika skraćivanja trajanja crvenog svjetla ima minimalno trajanje faze. Maksimalna vrijednost skraćivanja trajanja crvenog svjetla također se mijenja i ovisi o specifičnostima pojedinih raskrižja, te o matrici zaštitnih međuvremena, odnosno najkraćem vremenu potrebnom da pješaci prijeđu cestovnu prometnicu. Ova strategija je kao i tehnika produljenja trajanja zelenog svjetla, najčešća na raskrižjima s dvije signalne grupe [5].



Slika 4: Grafički prikaz tehnike ranije početka zelenog svjetla [5]

Dodatna faza za ciljanu skupinu vozila

U ovoj tehnici, nova faza dodana je u ciklus kako bi dala prioritet vozilu kojem je potreban prioritet. Tehnika dodavanja faze u ciklusu je isključivo primjenjiva na raskrižjima sa dvije ili više faza. Dobar primjer je dodavanje faze kada vozilo treba skrenuti lijevo na raskrižju s dvije faze. Na slici 5 grafički je prikazana tehnika dodavanja faze između postojeće faze 2 i faze 3 [5].



Slika 5: Grafički prikaz tehnike umetanja faze za ciljanu skupinu vozila [5]

Selektivne strategije

Selektivna strategija dodjele prioriteta uključuje odabir najpogodnije tehnike aktivne dodjele prioriteta s obzirom na predviđeno vrijeme dolaska vozila JGP-a na semaforizirano raskrižje. Odnosno ovisi o predviđenom vremenu dolaska odabranog vozila na semaforizirano raskrižje i o trenutnoj aktivnoj fazi u trenutku dolaska vozila na raskrižje [5], [8].

2.1.3 Prometno adaptivne strategije dodjele prioriteta

Na prometnoj mreži gdje se promet regulira neadaptivnim i nekoordiniranim signalnim planovima dolazi do nepotrebnog zaustavljanja i prekidanja prometnih tokova. ITS rješenja adaptivnog vođenja prometnog toka, rješava takve probleme te nastoji održati ukupnu razinu uslužnosti pojedinog raskrižja. U odnosu na koordinirani fiksni režim rada semafora, adaptivni je kompleksniji, ali i učinkovitiji. Adaptivne strategije nazivamo i stvarnovremenskim strategijama iz razloga što se odluka o promjeni signalnog plana osniva na stvarnovremenskim prometnim podacima. Kao takve, odluke o izmjenama signalnog plana zasnivaju se na težinskim faktorima ili na prethodno definiranim korisničkim algoritmima za donošenje odluka, a ne na predefiniranim strategijama dodjele prioriteta [1].

Adaptivno upravljanje signalnim planovima je bitna komponenta u ITS-u. ITS rješenje adaptivnog upravljanja prometnim tokom povećava propusnost tako da se redoslijed odlučivanja i trajanja ciklusa stalno prilagođavaju promjenjivim potrebama prometnog toka i uvjetima okruženja. Najčešće se koriste tri osnovna pristupa optimizacije rada prometno adaptivnih dodjela prioriteta [5], [9]:

- Klasični optimizacijski model;

- Modeli zasnovani na genetskim algoritmima i neuronskim mrežama;
- Algoritmi zasnovani na neizrazitoj logici.

2.2 Algoritam za dodjelu prioriteta zasnovan na duljini reda čekanja i praćenju vozila

Nesreće i medicinski hitni slučajevi kao što su požar, prometne nesreće, srčani udari itd. javljaju se svakodnevno. Važno je da žurne službe dođu do mjesta nesreće u što kraćem roku kako bi spasili ljudske živote. Tako se bolnice i vatrogasne stanice ravnomjerno postavljaju po gradu (urbanim sredinama) kako bi se smanjilo vrijeme odziva. Međutim, brz rast populacije u gradovima rezultirao je velikim gustoćama prometa na gradskim prometnicama. Prilikom putovanja po potrebnoj ruti, vozila žurnih službi najviše gube vremena na semaforiziranim raskrižjima. Razlog tome su osobni automobili u redu čekanja pred raskrižjem iako vozači ipak nastoje propustiti vozila žurnih službi i osloboditi im prostor za prolazak. Takav proces raščišćavanja je spor i nepouzdan, a uz to je i značajno narušena sigurnost sudionika u prometu.

Cilj algoritma za dodjelu prioriteta je smanjiti izgubljeno vrijeme vozila žurnih službi i povećati sigurnost svih sudionika u prometu utjecanjem na signalni plan raskrižja. Ulazni podaci na kojima je zasnovan algoritam su lokacija i brzina vozila žurne službe te broj vozila u redu čekanja na svim privozima raskrižju. U stvarnom sustavu lokaciju i brzinu vozila moguće je odrediti korištenjem GPS prijemnika dok se za određivanje broja vozila u redu čekanja mogu koristiti razni detektori, video prepoznavanje itd [3].

Algoritam za dodjelu prioriteta zasnovan na duljini reda čekanja i praćenju vozila se dijeli na dva dijela. Prvi dio algoritma omogućava raščišćavanje privoza te što nesmetaniji prolaz žurne službe kroz raskrižje. Nakon što žurna služba prođe kroz raskrižje, pokreće se drugi dio algoritma u svrhu vraćanja prometa u "normalu". Odnosno smanjenje negativnih učinaka uzrokovanih korištenjem algoritma za dodjelu prioriteta, te vraća promet u prvobitno stanje [3].

2.2.1 Algoritam za dodjelu prioriteta

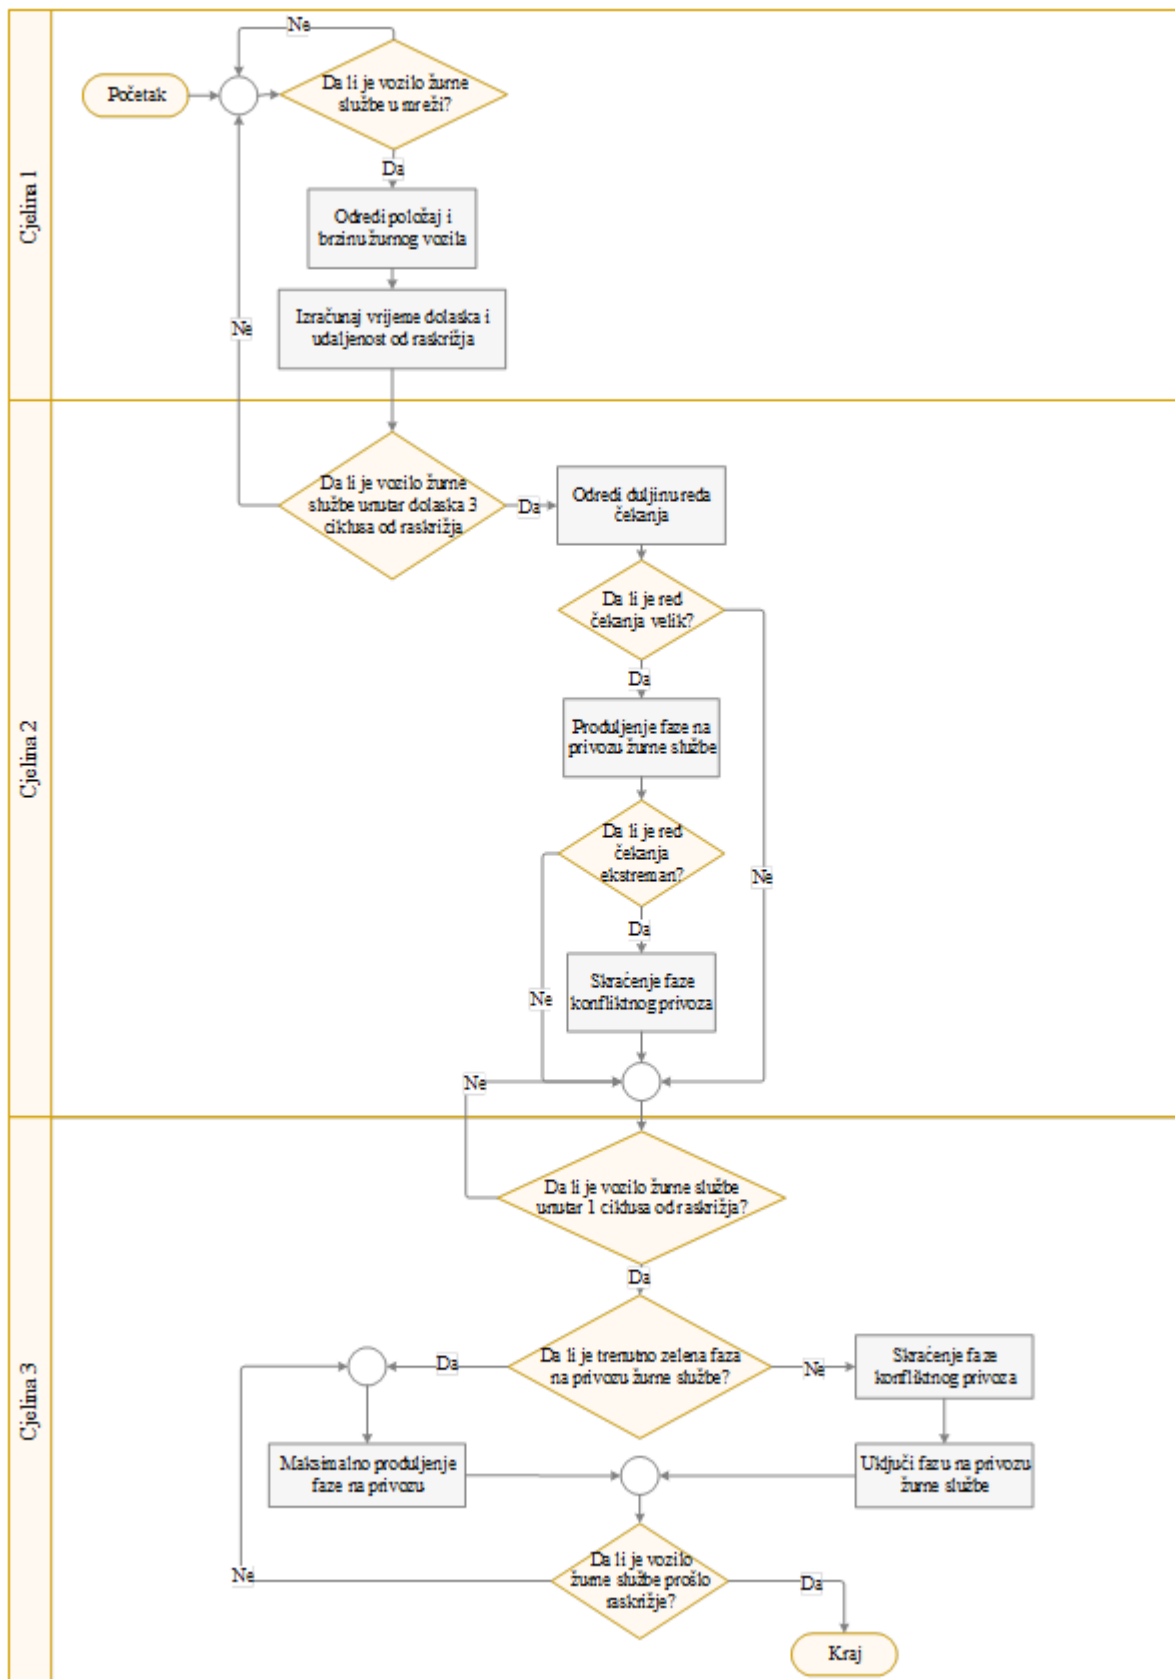
Zbog jednostavnosti i boljeg objašnjenja, algoritam je podijeljen u tri cjeline djelovanja [3]:

- **Cjelina 1** - Praćenje vozila žurne službe;
- **Cjelina 2** - Dodjela prioriteta zasnovana na duljini reda čekanja;
- **Cjelina 3** - Dodjela apsolutnog prioriteta.

U prvoj cjelini algoritma se detektira pojava vozila žurne službe na prometnoj mreži te se određuje kojom rutom prolazi i kojoj signalnoj grupi vozilo žurne službe pripada. Na osnovi lokacije i brzine vozila žurne službe izračunava se procjena vremena njegovog dolaska do semaforiziranog raskrižja. Nakon što je određena procjena dolaska vozila žurne službe unutar granica određenih vremenskih parametara započinje druga cjelina [3]

U drugoj cjelini algoritma se broje vozila u redu čekanja na privozu iz smjera dolaska žurnog vozila te se u slučaju zagušenosti, odnosno postojanja reda čekanja produžuje faza zelenog svjetla kako bi se dobilo više vremena za raščišćavanje vozila u pripadnom privozu. Iznimno se u slučaju jače zagušenosti skraćuje faza konfliktnih privoza. Procjena vremena dolaska vozila žurne službe na raskrižje se i dalje računa te ukoliko je procijenjen dolazak unutar trajanja jednog ciklusa signalnog plana započinje treća cjelina algoritma [3].

Treća cjelina algoritma dodjeljuje apsolutni prioritet nadolazećem vozilu žurne službe, odnosno u najbržem mogućem roku poštujući sigurnosne zahtjeve dodjeljuje zeleno svjetlo te ga drži sve do prolaska vozila žurne službe kroz raskrižje. Kada je dobiven signal potvrde prolaska vozila žurne službe kroz raskrižje algoritam završava [3].



Slika 6: Prikaz dijagrama toka algoritma za dodjelu prioriteta prema cjelinama [3]

2.2.2 Algoritam vraćanja oduzetog vremena

Primjenom algoritma za dodjelu prioriteta stvara se neizbježan negativan utjecaj na ostatak prometa, odnosno na konfliktne privoze. Kako bi se smanjio negativan utjecaj korišten je algoritam povratka oduzetog vremena. Predloženi algoritam povratka oduzetog vremena iz [10] daje ravnomjerni povrat (engl. round robin) gdje svakoj zakinutoj fazi vraćeno vrijeme jednako oduzetom vremenu. U ovom radu korištena je nadogradnja algoritma iz [10]. Umjesto ravnomjernog povrata oduzetog vremena uzet je u obzir odnos trajanja pojedinih faza fiksnog signalnog plana. Nakon što završi algoritam dodjele prioriteta izračunava se ukupno skraćeno vrijeme prema izrazu 1.

Nakon algoritma dodjele prioriteta i izračuna ukupnog skraćenog vremena vrši se povrat oduzetog vremena raspodijeljen periodično unutar nekoliko ciklusa signalnog plana [3].

$$T_{povratak} = T_{oduzeto} \cdot \frac{t_1}{t_2}, \quad (1)$$

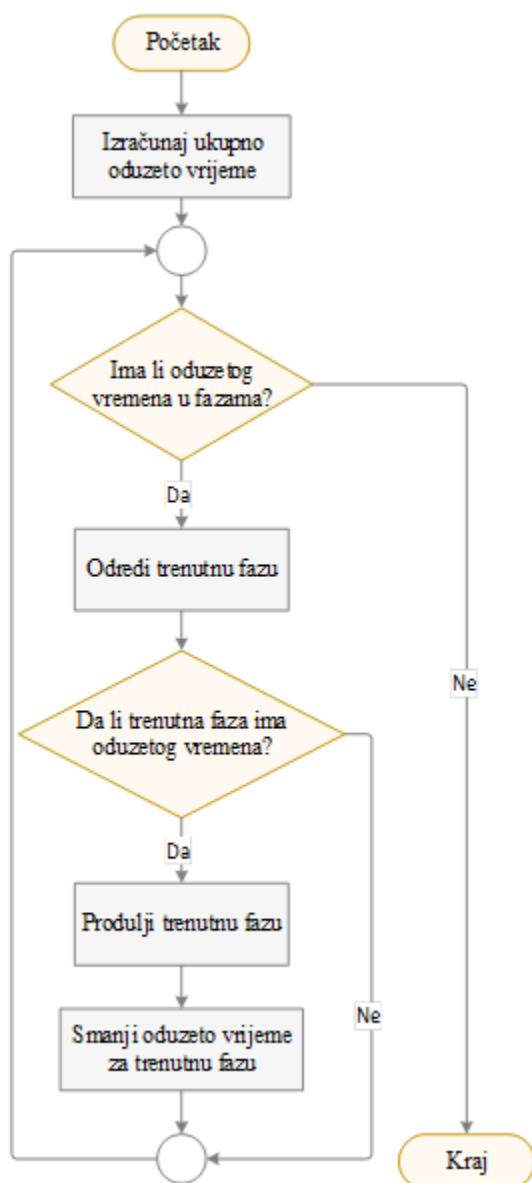
gdje je:

$T_{povratak}$ - ukupno vrijeme vraćeno zakinutoj fazi [s];

$T_{oduzeto}$ - ukupno vrijeme oduzeto zakinutoj fazi [s];

t_1 - trajanje zakinute faze [s];

t_2 - trajanje konfliktne faze [s].



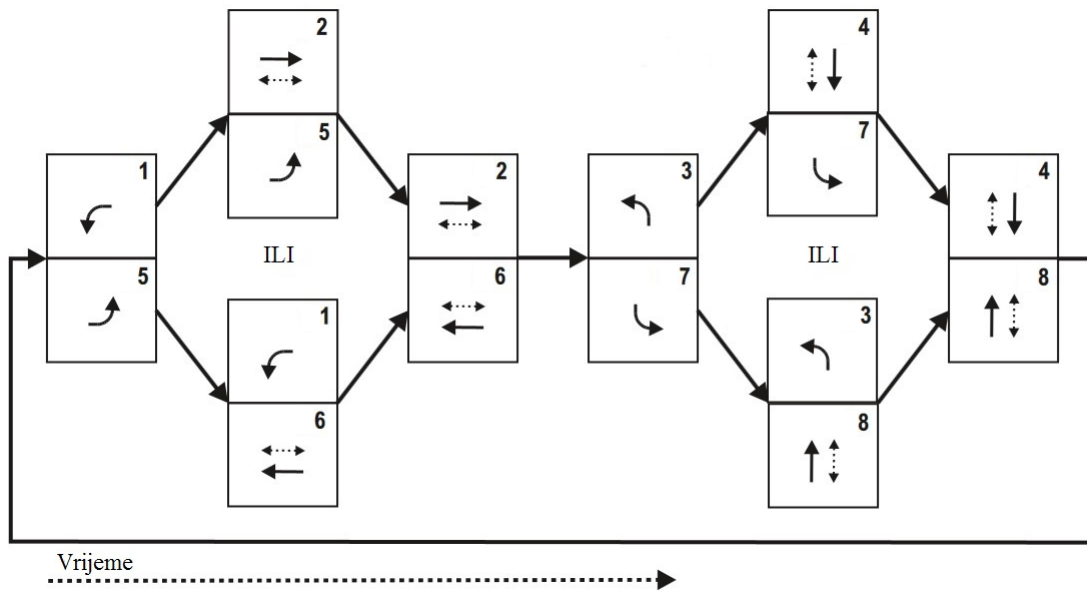
Slika 7: Prikaz dijagrama toka algoritma povratka oduzetog vremena [3]

3 NEMA struktura signalnih planova

Signalne uređaje, odnosno uređaje koji upravljaju izvođenjem signalnog plana na semaforiziranom raskrižju može se podijeliti na fiksno programirane i prometno ovisne. Svaka vrsta upravljanja ima svoje jedinstvene prednosti i nedostatke. Ne postoji optimalni način za određivanje najboljeg tipa upravljača za svako raskrižje. Fiksno programirani su uglavnom jeftinije izvedbe i jednostavnijeg održavanja dok prometno ovisni iako skuplji mogu doprinijeti smanjenju izgubljenog vremena, povećanju kapaciteta prometnice, te mogu biti sigurniji od fiksno programiranih. Većina današnjih signalnih uređaja sadrži mikroprocesore, te su uglavnom kategorizirani kao NEMA (engl. National Electrical Manufacturers Association) upravljači ili upravljači tipa 170 [11].

NEMA upravljači su jedinice koje odgovaraju određenom broju standarda za široku paletu opreme i uređaja. Upravljački model 170 je jedinica opće namjene, mikroračunalno koje je dio standardiziranog sklopa regulatora. Sklop kao takav nema nikakvu funkcionalnost bez omogućene programske podrške za upravljanje signalnim planom. Kada je programiran pomoću odgovarajuće programske podrške, upravljački model 170 je u mogućnosti obavljati iste funkcije kao i NEMA upravljač [11], [12].

Korištenjem NEMA upravljača i standarda omogućuje se izvođenje signalnog plana prema prstenastoj strukturi. Prsten je izraz koji se koristi za opisivanje niza konfliktnih faza koje se javljaju u zadanom poretku. Prstenasta struktura može biti konstruirana od jednog, dva ili više prstena. Primjer dvostruke prstenaste strukture dan je na slici 8. Prstenasta struktura čini mijenjanje signalnih planova jednostavno, pametno i sigurno [11]. U ovom radu NEMA prstenasta struktura je korištena kao podloga za izradu i upravljanje modela signalnog uređaja. Osim samog slijeda faza unutar signalnog plana, u radu prstenasta struktura je proširena dodatno s podacima o zaštitnom međuvremenu između faza, jedinstvenom oznakom, imenom, te oznakom za signalni uređaj unutar simulacije.



Slika 8: Prikaz dvostruke prstenaste strukture NEMA upravljača u osam faza [3]

4 Simulacijsko okruženje PTV

VISSIM/MATLAB

U ovom poglavlju opisani su programski alati PTV VISSIM i MATLAB korišteni za simulaciju prometne mreže i implementaciju algoritma dodjele prioriteta vozilima žurnih službi.

4.1 Simulacijski alat PTV VISSIM

Za simuliranje prometa korišten je simulacijski alat VISSIM tvrtke PTV. PTV VISSIM je mikroskopski simulacijski alat za modeliranje gradske prometne mreže i operacija prometnih entiteta. Služi za analizu i optimizaciju prometnih tokova. Jedan je od najmoćnijih dostupnih alata za simuliranje više modalnih mreža prometa i prometnih entiteta. Mikroskopska simulacija omogućuje simuliranje svakog prometnog entiteta individualno, odnosno svakog automobila, autobusa, biciklista, tramvaja, pješaka i slično. Točnost i vjerodostojnost evaluacije podataka simulacijskog modela najviše ovisi o samoj kvaliteti izrade modela ponašanja prometnih entiteta u simuliranoj prometnoj mreži. VISSIM pokazuje sve sudionike u prometu i interakcije u jednom modelu. Karakteristike vozača i vozila omogućavaju pojedinačnu parametrizaciju. Osim toga, omogućuje sučelja za jednostavnu integraciju s drugim aplikacijama za vezu sa signalnim upravljačima, sustavom za upravljanje prometom ili modelom za izračun emisije ispušnih plinova. Korišten je za analizu mreža od reda veličina jednog pojedinačnog raskrižja pa sve do veličine mreže cijelog grada. Unutar tih prometnih mreža, moguće je klasificirati prometnice na autoceste i gradske ceste [5], [13].

Mikroskopska simulacija prometa predstavlja promet u puno više detalja nego makroskopska ili mezoskopska. Zbog velikih detalja i točnijeg provođenja rezultata, klasificirana je kao model visoke vjernosti. U VISSIM-u podaci se mogu uzimati i analizirati u bilo kojem

vremenu u bilo kojem vremenskom prozoru. Podaci se mogu uzimati s bilo koje lokacije na mreži, na samome raskrižju, dijelu prometnice ili/i na cijeloj mreži. Podaci se mogu skupljati ovisno o načinu rada ili ovisno o klasi vozila. Pristupiti se može i individualnom vozilu, te analizirati njegove parametre. Mogu se mjeriti brojne mjerne jedinice efektivnosti, kao što su vrijeme kašnjenja, vrijeme putovanja, gustoća prometa, broj stajanja, redovi čekanja itd. [9], [14].

U mikroskopskim simulacijama bez obzira na arhitekturu, algoritme i protok informacija, postoje algoritmi i funkcije koji su jezgreni i ne mijenjaju se. Postoji sedam jezgrenih modula u VISSIM-u [9]:

1. **Modul generiranja slučajnih brojeva:** slučajnih brojeva: generira slučajne brojeve za primjenu u raznim metodama koje utječu na tijek simulacije;
2. **Modul atributa vozila i vozača:** definira attribute i karakteristike vozila te vozača koji ulaze u prometnu mrežu;
3. **Modul generiranja vozila:** definira kada i gdje će vozilo ući u prometnu mrežu;
4. **Modul praćenja vozila:** definira kako će vozilo ubrzavati, usporavati i pratiti druga vozila;
5. **Modul mijenjanja prometne trake:** kako i kad će vozilo promijeniti prometnu traku;
6. **Modul signalnog uređaja:** upravlja signalnim planovima u prometnoj mreži;
7. **Animacijski modul:** prikazuje animaciju vozila u prometnoj mreži, rad animacijskog modula prikazan je na slici 9.




Slika 9: Prikaz izvođenja simulacije raskrižja u VISSIM-u [3]

VISSIM koristi psihofizički Wiedemannov model kojeg je razvio 1974. godine Rainer Wiedemann na Sveučilištu u Karlsruheu. Wiedemannov model definira percepcije vozača i njihove reakcije. U VISSIM-u postoje dva različita modela ponašanja. Wiedemann 74 je prilagođen urbanom prometu, a Wiedmann 99 brzom prometu na autocestama. Oba modela su vrlo slična, ali ih razlikuju parametri isto kao što se u stvarnom svijetu razlikuje ponašanje vozača na autocesti i u urbanom prometu. Atributi koji opisuju svaku jedinicu "čovjek-vozilo" mogu se kategorizirati u tri osnovne skupine [15]:

- **tehničke specifikacije vozila** - duljina vozila, najveća brzina, potencijalno ubrzanje i usporavanje, duljina samog vozila, trenutna pozicija vozila u prometnoj mreži, itd.;
- **ponašanje jedinice "čovjek-vozilo"** - karakteristike psihofizičkih pragova osjetljivosti vozača;
- **međusobna zavisnost jedinica "čovjek-vozilo"** - ponašanje vozila u koloni i susjednim trakovima, odnos vozila prema prometnici i signalnim planovima, itd.

Stohastička priroda prometnog sustava uvjetuje simulacijskim alatima potrebu varijabilnosti. U ovom radu zbog izrade urbane mreže korišten je Wiedemann 74 model prema parametrima definiranim u VISSIM-u. Definirani parametri su prosječna udaljenost do prethodnog vozila prilikom stajanja i faktori za kreiranje razdiobe sigurnosne udaljenosti između vozila tijekom vožnje.



Slika 10: Prikaz sučelja u programskom simulatoru VISSIM

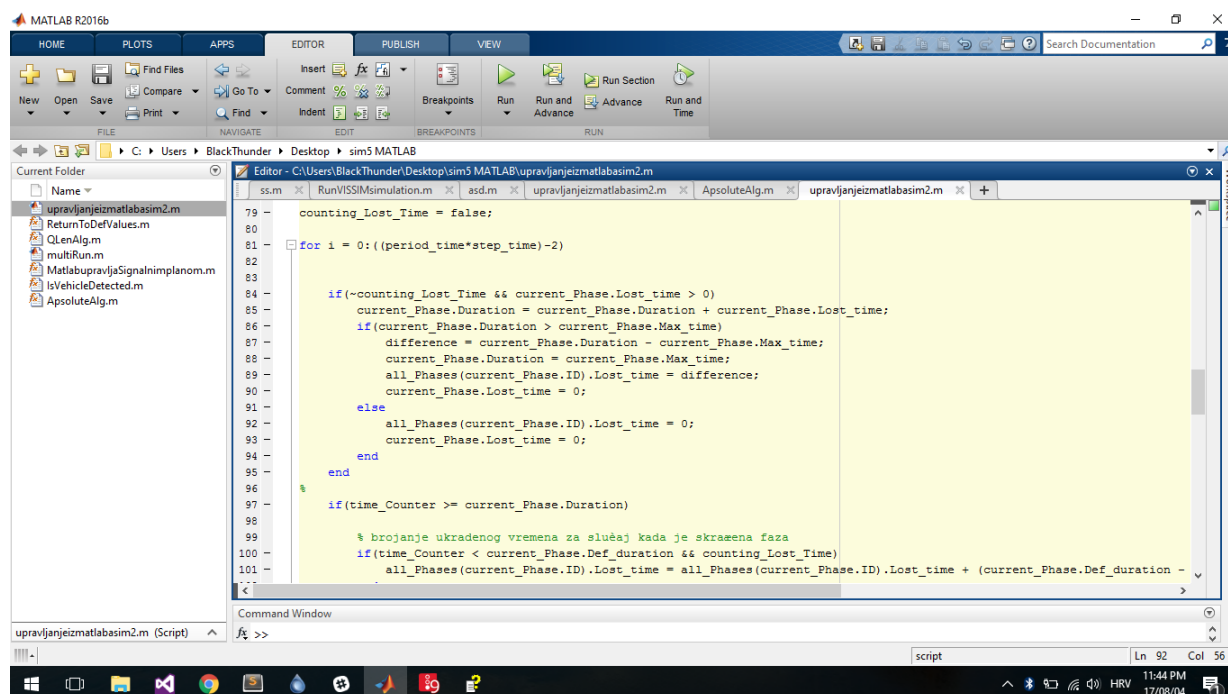
4.2 Programski paket MATLAB

MATLAB je interaktivni programski sustav za rješavanje različitih matematičkih problema, te izvođenje čitavog niza izračuna i simulacija vezanih uz obradu signala, upravljanje i identifikaciju sustava. Ime programskog sustava MATLAB dolazi od skraćenice njegovog primarnog svojstva - matričnog kalkulatora, odnosno laboratorija (engl. MATrix LABoratory). MATLAB programski sustav moguće je definirati kao okruženje s programskim jezikom namijenjeno tehničkim izračunima. Obuhvaća izračune, vizualizaciju i programiranje u jednostavnoj okolini. Rješava sustave linearnih jednadžbi, računalnih svojstvenih vrijednosti i svojstvenih vektora. MATLAB je također i odličan alat za rješavanje algebarskih i diferencijalnih jednadžbi te numeričke integracije. Ima korisne grafičke alate koji mogu reproducirati slike u 2D i 3D. MATLAB sadrži i programski jezik visokih performansi. Integrira računanje, vizualizaciju i programiranje u interaktivnu okolinu jednostavnu za korištenje. U njoj su problemi i rješenja izraženi u matematičkim notacijama. Podržava napredne strukture podataka, ima ugrađeni alat za uređivanje i ispravljanje pogrešaka (engl. debugging tool), te objektno orijentirano programiranje. MATLAB, također

ima mnoge prednosti u usporedbi s uobičajenim računalnim jezicima (npr. C, FORTRAN) za rješavanje tehničkih problema. MATLAB je interaktivni sustav čiji osnovni elementi podataka su nizovi koji ne zahtijevaju dimenzioniranje. Softverski paket je komercijalno dostupan od 1984. godine i sada se smatra standardnim alatom na brojnim sveučilištima i industrijama diljem svijeta. Osnovna svojstva MATLAB-a su prema [16], [17], [18] sljedeća:

- Matrični kalkulator interpreterskog tipa;
- Grupiranje naredbi u skripte i funkcije;
- Otvorenost – razvoj skupova alata za rješavanje specifičnog tipa problema (engl. toolbox);
- Testiranje algoritama u stvarnom vremenu.


U ovom radu MATLAB je korišten kao upravljačka jedinica za adaptivno upravljanje signalnim planom prema simuliranim podacima o položaju žurnog vozila i podacima o duljini reda čekanja dobivenih iz VISSIM-a.



Slika 11: Prikaz sučelja u programskom paketu MATLAB

4.3 Povezivanje MATLAB-a i VISSIM-a pomoću COM sučelja

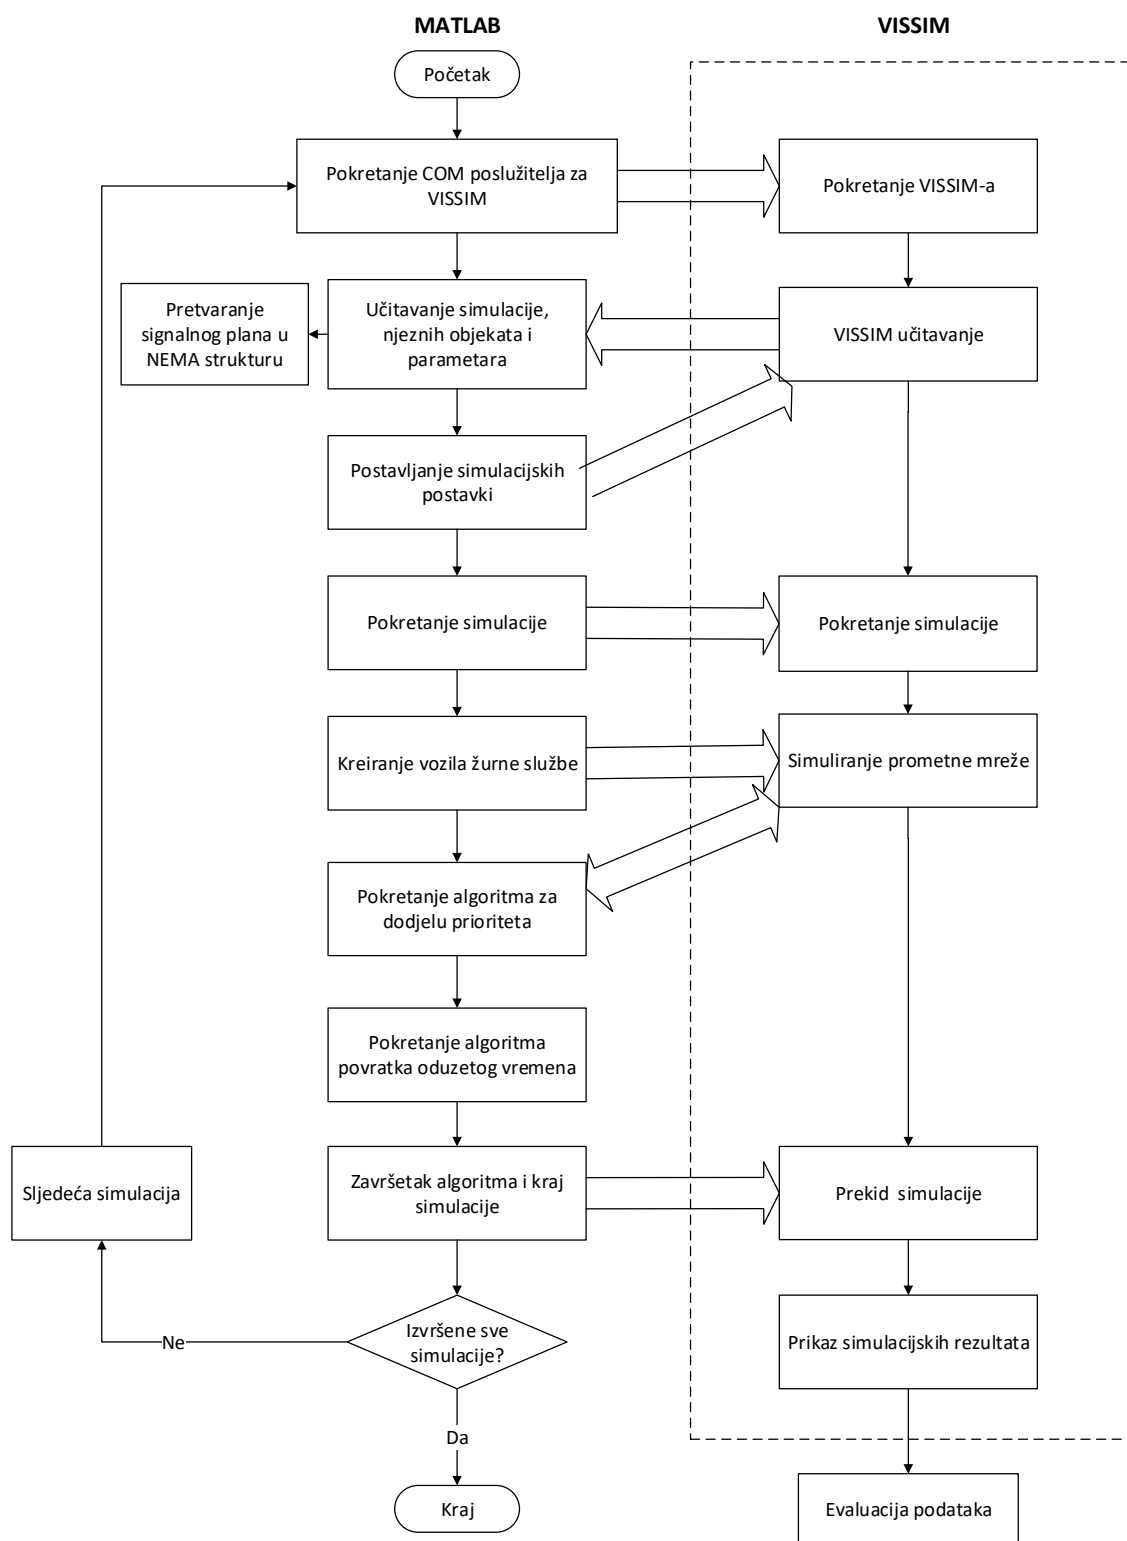
Algoritam adaptivnog upravljanja semaforiziranim raskrižjem napravljen je u MATLAB programskom paketu, a simulacijski dio u VISSIM aplikaciji. Oba alata povezana su preko COM (engl. Component Object Model, COM) sučelja, čime im je omogućena komunikacija. Komponentni objektni model (COM) je osnovni model arhitekture koja omogućuje povezivanje i interakciju između dvije različite vrste složenih programskih alata koji su proizvedeni od strane dva različita proizvođača. Omogućuju korisniku različite funkcionalnosti, ali sve dijele istu potrebu za mehanizmom koji omogućava da binarni programski dijelovi proizvedeni od strane različitih proizvođača međusobno komuniciraju na unaprijed dogovoren i strogo određen način. Zahvaljujući takvoj lakoj dostupnosti i transparentnosti COM je otvoreni standard i sva dokumentacija je javna za sve razine protokola. COM je programski model osnovan na objektima, osmišljen za laku međusobnu komunikaciju čak i ako su ih napisali različiti proizvođači u različito vrijeme, na različitim jezicima i ako se izvode na različitom sklopovlju s različitim operativnim sustavima. COM omogućuje klijentu komunikaciju, te potražnju i spajanje na potrebnu uslugu. Nakon što je jednom veza uspostavljena, COM se otpušta i sva daljnja komunikacija između poslužitelja i klijenta je izravna [19], [20], [21].



Slika 12: COM veza između klijenta i poslužitelja [20]

U ovom radu COM sučeljem su povezane aplikacije VISSIM i MATLAB, gdje je MATLAB klijentska, a VISSIM poslužiteljska aplikacija. Simulacija u VISSIM-u sadrži simulacijske parametre i podatke dobivene mjerenjem ponašanja simulacije. Kao ulazni parametri u MATLAB-u koriste se podaci o signalnom planu na raskrižju i žurnom vozilu. Korištenjem tih podataka algoritam adaptivnog upravljanja signalnim planom po potrebi izmjenjuje signalni plan ovisno o položaju vozila žurne službe. Nakon što se signalni plan izmjeni, MATLAB šalje simulacijske parametre u VISSIM, te VISSIM nastavlja s odvijanjem simulacije s novim parametrima, odnosno novim signalnim planom. Po završetku simulacije podaci iz VISSIM-a su spremni za daljnju detaljniju analizu i obradu.

Na slici 13 prikazan je dijagram toka izvršavanja simulacija. Dijagram pokazuje interaktivni proces između programskog paketa MATLAB i simulatorskog programa VISSIM. Proces započinje pokretanjem MATLAB skripte koja pokreće više skripti unutar petlje za pokretanje više simulacija jedne za drugom s promjenom slučajnog sjemena (engl. random seed) generatora vrijednosti slučajnih varijabli. Svaka simulacija, odnosno pokrenuta skripta prvo pokreće VISSIM COM poslužitelj koji zatim pokreće VISSIM. Nakon toga MATLAB učitava VISSIM model i simulaciju, prometnu mrežu i njegove objekte poput signalnih upravljača, poveznice (engl. links), osjetila na prometnicama, entitete u mreži, itd. Očitava signalne planove postavljene unutar VISSIM-a i pohranjuje ih u NEMA strukturu za lakše upravljanje signalnim planovima. Nakon toga MATLAB skripta postavlja potrebne postavke simulacije poput perioda trajanja simulacije, rezolucije simulacije i volumen vozila na prometnicama. Nakon postavljenih svih postavki potrebnih za izvršavanje i testiranje simulacije i algoritma, iz MATLAB-a se pokreće VISSIM simulacija. Za vrijeme simulacije kreira se vozilo žurne službe koje se zatim prati i pokreće algoritam dodjele prioriteta. Nakon što je vozilo žurne službe prošlo zadano raskrižje, pokreće se algoritam povratka oduzetog vremena. Po završetku algoritma povratka oduzetog vremena završava se simulacija, te pokreće sljedeća u nizu s novim sjemenom za generiranje slučajnih varijabli. Nakon što su sve simulacije izvršene unutar VISSIM-a, prikupljaju se simulacijski rezultati te vrši analiza rezultata.



Slika 13: Dijagram slijeda spajanja programskog paketa MATLAB i simulacijske aplikacije VISSIM

5 Generiranje i praćenje vozila žurnih službi u PTV VISSIM-u

5.1 Postavljanje vozila u mrežu

Postavljanje specifičnog tipa vozila u određenim vremenskim okvirima unutar VISSIM-a poput onog opisanog u [3] je složeno i neprecizno. Zahvaljujući upravljanju iz MATLAB-a moguće je postaviti željeno vozilo sa zadanim pravilima kroz sljedeće naredbe:

- **vissim = actxserver('VISSIM.Vissim.900');** - Naredba pokreće i pristupa VISSIM-ovom *ActiveX* COM poslužitelju te sprema taj objekt u varijablu *vissim*;
- **vissim.LoadNet(putanja.inpx);** - Naredba učitava prometnu mrežu s putanje datoteke *putanja.inpx* u očitano poslužitelja;
- **vissim.LoadLayout(putanja.layx);** - Naredba učitava simulacijsku okolinu s putanje datoteke *putanja.layx* u očitano poslužitelja;
- **simulacija = vissim.Simulation;** - Naredba pristupa simulacijskim objektima iz očitane simulacije te sprema objekt u varijablu *simulacija*. Ovaj pristup je potreban kako bi se postavile osnovne simulacijske postavke poput rezolucije simulacije, nasumičnog sjemena, trajanje simulacije itd;
- **mreža = vissim.Net;** - Naredba pristupa mrežnim objektima iz očitane simulacije te sprema objekt u varijablu *mreža*;
- **sva_vozila = mreža.Vehicles;** - Naredba učitava listu svih objekta vozila iz prometne mreže u VISSIM simulaciji te sprema objekt u varijablu *sva_vozila*;
- **sva_vozila.AddVechicleAtLinkPosition(VehicleType, Link, Lane, Position, DesiredSpeed, Interaction)** - Naredba dodaje željeno vozilo u listu objekta vozila. Me-

toda dodaje vozilo opisano s pet obaveznih parametara ili šest s opcionalnim parametrom. Postavlja novo vozilo specificiranog tipa na navedenu traku i poveznicu. Standardni način primjene ove metode omogućava stavljenom vozilu u mrežu da međusobno djeluje sa susjednim vozilima prema trenutnoj situaciji i željenoj brzini. Alternativno, moguće je postaviti međusobno djelovanje na lažno te zanemarivanje uvjeta protoka prometa, putujući željenom brzinom bez obzira na druga vozila i mrežne objekte. Prvi parametar *VehicleType* je cijeli broj koji označava željenu skupinu vozila, u ovom radu unutar VISSIM-a ručno je napravljen i stavljen model žurne službe kao posebna skupina vozila sa zadanim pravilima. Drugi, treći i četvrti parametar opisuju točnu lokaciju generiranja vozila na prometnici, drugi parametar *Link* označuje poveznicu na kojoj se stvara vozilo, treći parametar *Lane* označuje traku unutar poveznice, te četvrti parametar *Position* označuje poziciju po dužini poveznice. Peti parametar *DesiredSpeed* je željena brzina vozila u kilometrima na sat, te šesti opcionalni parametar *Intersection* označava "zastavicu" za poštivanje prometa koja može biti istina ili laž. Potpis metode iz VISSIM COM Pomoći (engl. Help) prikazan je na slici 14.

Syntax


Visual Basic

```
Public Function AddVehicleAtLinkPosition( _  
    ByVal VehicleType As Variant, _  
    ByVal Link As Variant, _  
    ByVal Lane As Integer, _  
    ByVal Position As Double, _  
    ByVal DesiredSpeed As Double, _  
    Optional ByVal Interaction As Boolean = True _  
) As IVehicle
```

Slika 14: Prikaz potpisa metode za dodavanje vozila unutar COM pomoći u VISSIM-u

5.2 Praćenje položaja vozila žurnih službi

U ovom radu VISSIM je korišten kao simulator GPS podataka, gdje stvarne GPS podatke zamjenjuje izračun položaja vozila na cestovnoj poveznici (engl. link). Takav podatak o položaju se može koristiti za izračun udaljenosti od raskrižja uz poznavanje duljine cestovne poveznice. Kako bi se omogućio takav način računanja potrebno je prilikom modeliranja raskrižja i cestovne mreže u VISSIM-u prilagoditi početak i kraj cestovne poveznice. Odnosno svaka poveznice mora započeti i završiti pred raskrižjem. Za spajanje tih poveznica koriste se spojne poveznice. Metoda izračuna položaja prikazana je na slici 15 i dana izrazom 2. Na slici 15 brojevima su označene cestovne poveznice, te je vidljivo da se poveznice nadovezuju jedna na drugu. U konačnici se povezuju na raskrižje koje se sastoji od spojnih poveznica [3].



Slika 15: Metoda izračuna udaljenosti od raskrižja poznavanjem duljine spojnice i položaja na spojnici [3]

Poznavanjem rute vozila žurne službe, odnosno slijeda poveznica koje vozilo žurne službe treba proći da dođe do razmatranog raskrižja, moguće je odrediti udaljenost žurne

službe do razmatranog raskrižja korištenjem sljedećeg izraza:

$$L_R = \sum_{i=1}^k L_{Li} + L_{LT} - L_V, \quad (2)$$

gdje je:

L_R - udaljenost vozila žurne službe od raskrižja [m];

k - broj cijelih poveznica između raskrižja i vozila žurne službe kroz koje vozilo žurne službe još nije prošlo;

L_{Li} - duljina i -te poveznice između raskrižja i vozila žurne službe [m];

L_{LT} - duljina poveznice na kojoj se trenutno nalazi vozilo žurne službe [m].

L_V - položaj vozila žurne službe u odnosu na početak poveznice na kojoj se vozilo žurne službe trenutno nalazi [m].

Korištenjem COM sučelja omogućeno je upravljanje i učitavanje stanja objekata unutar VISSIM-a kroz metode u MATLAB-u. Kako bi se omogućilo praćenje vozila unutar MATLAB-a nakon što su učitani svi objekti u prethodnom potpoglavlju, korištene su sljedeće metode:


- **trenutna_poveznicaID = sva_vozila(br_voz).get('AttValue', Lane\Link);** - Naredba koja učitava jedinstveni broj trenutne poveznice na kojoj se vozilo žurne službe nalazi i sprema ga u varijablu *trenutna_poveznicaID*;
- **pozicija_žurnog_vozila = all_vehicles(br_voz).get('AttValue', Pos);** - Naredba koja učitava trenutnu poziciju vozila žurne službe na poveznici te sprema u varijablu *pozicija_žurnog_vozila*;
- **brzina_žurnog_vozila = all_vehicles(br_voz).get('AttValue', Speed);** - Naredba koja učitava trenutnu brzinu vozila žurne službe te ju sprema u varijablu *brzina_žurnog_vozila*.

6 Rezultati simulacije

6.1 Prometni model i podaci

Model korištenog raskrižja


Kako bi se testirali i usporedili izrađeni algoritmi napravljen je model raskrižja "Ulica kralja Zvonimira - Harambašićeva ulica" prikazano na slici 16. Uzeto raskrižje se nalazi na jednom od glavnih koridora koji povezuju grad Zagreb s istoka na zapad i obrnuto. Dva prilaza od Zvonimirove ulice sastoji se od dva traka u oba smjera, dok oba prilaza Harambašićeve ulice imaju po jedan prometni trak u svakome smjeru. Također, na Zvonimirovoj ulici nalazi se tramvajska pruga kojom prolaze tramvajske linije brojeva 17, 9, te 1. Na slici 16 sivo su označene cestovne površine, smeđe su prikazane tračnice tramvaja, dok plavi pravokutnici predstavljaju detektore korištene za potvrdu prolaska vozila žurne službe.



Slika 16: Model raskrižja "Ulica kralja Zvonimira - Harambašićeva ulica"

Signalni plan

Ustaljeni signalni plan definiran je kroz dvije slijedne faze. Prva faza je glavni prometni tok Ulicom kralja Zvonimira sa zelenim svjetlom u trajanju od 42 sekundi, dok je druga faza sporedni tok Harambašićevom ulicom sa zelenim svjetlom u trajanju od 35 sekundi.



Slika 17: Prikaz signalnog plana raskrižja "Ulica kralja Zvonimira - Harambašićeva ulica" u VISSIM-u [3]

6.2 Postavke simulacije i rute vozila

Postavke simulacije

U ovom poglavlju je dan prikaz i analiza rezultata korištenja algoritma za dodjelu prioriteta vozilima žurnih službi te algoritma za vraćanje oduzetog vremena koji su opisani u potpoglavlju 2.2. Rezultati su grupirani prema zadanim prometnim scenarijima. Zbog stohastičke prirode prometnog sustava za svaki scenarij je simulirano deset različitih simulacija koje se međusobno razlikuju primjenom slučajnog sjemena generatora vrijednosti slučajnih varijabli. Primjenom slučajnih varijabli utječe se na vremensku raspodjelu generiranja prometne potražnje i na dolazak žurnog vozila u prometnu mrežu. Utjecanjem na vremensku raspodjelu prometne potražnje se ne utječe na ukupan broj

vozila koje ulazi u mrežu već samo na vrijeme ulaska pojedinog vozilo. Svaka simulacija je simulirana u trajanju od 3600 simulacijskih sekundi. Prvih 900 sekundi simulacije je korišteno za punjenje simulacijske mreže vozilima iz razloga što VISSIM simulaciju započinje bez vozila u mreži. Kako bi se izbjegao negativan utjecaj na rezultate, tijekom punjenja mreže nisu mjereni prometni parametri [3], [22].

Rute vozila

U svrhu testiranja algoritama i modela raskrižja, postavljene su dvije različite rute vozila žurnih službi. Osim dvije rute vozila, postavljene su i dvije različite prometne potražnje na prometnicama, vidljive u tablici 1. Ukupno čine četiri različita scenarija prolaska vozila žurne službe kroz zadano semaforizirano raskrižje [3], [22].

Scenarij 1 - Vozilo žurne službe prilazi raskrižju Zvonimirovom ulicom iz smjera istoka te nakon raskrižja nastavlja Zvonimirovom ulicom u smjeru zapada. Nakon slučajnog vremena u rasponu od 13 do 23 minute vozilo žurne službe se vraća istim putem. Prometno opterećenje je zadano prema brojanju prometa u razdoblju od 15:00h do 16:00h prema podacima iz [5].


Scenarij 2 - Vozilo žurne službe prilazi na identičan način kao u scenariju 1 uz povećanje prometnog opterećenja za 40% čime se simulira vršni sat.

Scenarij 3 - Vozilo žurne službe prilazi raskrižju Zvonimirovom ulicom iz smjera istoka te nakon raskrižja nastavlja Harambašićevom ulicom u smjeru sjevera. Nakon slučajnog vremena u rasponu od 13 do 23 minute vozilo žurne službe se vraća istim putem. Prometno opterećenje je identično opterećenju u scenariju 1.

Scenarij 4 - Vozilo žurne službe prilazi na identičan način kao u scenariju 3 uz povećanje prometnog opterećenja za 40% kako bi se ispitao rad algoritma u vršnom satu.

Tablica 1: Zadano prometno opterećenje u ovisnosti o prometnom scenariju

| Prometni scenarij | Prometno opterećenje [voz/h] | | | |
|-------------------|------------------------------|-----|-------------------|-------|
| | Harambašićeva ulica | | Zvonimirova ulica | |
| | Sjever | Jug | Istok | Zapad |
| 1 | 220 | 150 | 1100 | 720 |
| 2 | 350 | 210 | 1540 | 1008 |
| 3 | 220 | 150 | 1100 | 720 |
| 4 | 350 | 210 | 1540 | 1008 |




Slika 18: Prikaz smjera dolaska (zeleno) i povratka (crveno) vozila žurne službe: a) Scenarij 1 i 2; b) Scenarij 3 i 4 [3]

6.3 Analiza dobivenog vremena putovanja

U svrhu evaluacije predloženih algoritama na raskrižju, svaki od prethodno opisanih scenarija simuliran je po 10 puta u 4 različite konfiguracije. Simulirano je po 10 puta za svaki scenarij bez algoritma upravljanja, uz algoritam dodjele prioriteta, te uz algoritam dodjele prioriteta i povratka oduzetog vremena bez normiranjem te s normiranjem povratka oduzetog vremena. Algoritam dodjele prioriteta i povratka oduzetog vremena s normiranjem koristi predloženi algoritam vraćanja oduzetog vremena iz potpoglavlja 2.2.2, dok algoritam dodjele prioriteta bez normiranja koristi ravnomjerni povrat oduzetog vremena svakoj zakinu fazi. Za svaki scenarij mjereni je parametar vremena trajanja putovanja vozila žurne službe, kao jedan od glavnih indikatora poboljšanja i optimizacije

kretanja vozila žurnih službi. Vrijeme trajanja putovanja vozila žurnih službi prikazuje vrijeme mjereno od trenutka pojave vozila žurne službe u simuliranoj mreži do izlaska iz prometne mreže.


Prema parametrima scenarija 1 ukupno vrijeme putovanja vozila žurne službe prikazano je u grafikonu 1. Iz grafikona vidljivo je smanjenje vremena putovanja vozila žurne službe u svih 10 simulacija primjenom algoritma bez povratka vremena i s povratkom vremena. Bez algoritma vozilo žurne službe prosječno je putovalo 454 sekundi kroz 10 simulacija. Primjenom algoritma bez povratka vremena, vozilo žurne službe je prosječno putovalo 407 sekundi. Primjenom dodatnog algoritma za povratak vremena bez normiranja, vozilo žurne službe prosječno je putovalo 405 sekundi. Primjenom dodatnog normiranja algoritma za povratak vremena, vozilo žurne službe je putovalo 409 sekundi. Prosječno smanjenje ukupnog vremena putovanja u odnosu na prolazak vozila žurne službe bez algoritma iznosi 47 sekundi.



Grafikon 1: Ukupno vrijeme putovanja vozila žurne službe za prvi scenarij


Prema parametrima scenarija 2 ukupno vrijeme putovanja vozila žurne službe prikazano je u grafikonu 2. U scenariju 2 kao i u scenariju 1, na grafikonu vidljivo je smanjenje ukupnog vremena putovanja primjenom algoritma u svih deset simulacija simulacija.

Bez algoritma vozilo žurne službe prosječno je putovalo 524 sekundi kroz 10 simulacija. Primjenom algoritma bez povratka vremena, vozilo žurne službe je prosječno putovalo 467 sekundi. Primjenom dodatnog algoritma za povratak vremena bez normiranja, vozilo žurne službe prosječno je putovalo 450 sekundi. Primjenom dodatnog normiranja algoritma za povratak vremena, vozilo žurne službe je putovalo 451 sekundi. Prosječno smanjenje ukupnog vremena putovanja u odnosu na prolazak vozila žurne službe bez algoritma iznosi 73 sekundi.




Grafikon 2: Ukupno vrijeme putovanja vozila žurne službe za drugi scenarij

Prema parametrima scenarija 3 ukupno vrijeme putovanja vozila žurne službe prikazano je u grafikonu 3. U scenariju 2 kao i u scenariju 1, na grafikonu vidljivo je smanjenje ukupnog vremena putovanja primjenom algoritma u svih deset simulacija. Bez algoritma vozilo žurne službe prosječno je putovalo 456 sekundi kroz 10 simulacija. Primjenom algoritma bez povratka vremena, vozilo žurne službe je prosječno putovalo 416 sekundi. Primjenom dodatnog algoritma za povratak vremena bez normiranja, vozilo žurne službe prosječno je putovalo 410 sekundi. Primjenom dodatnog normiranja algoritma za povratak vremena, vozilo žurne službe je putovalo 410 sekundi. Prosječno smanjenje ukupnog vremena putovanja u odnosu na prolazak vozila žurne službe bez algoritma iznosi 45 sekundi.




Grafikon 3: Ukupno vrijeme putovanja vozila žurne službe za treći scenarij

Prema parametrima scenarija 4 ukupno vrijeme putovanja vozila žurne službe prikazano je u grafikonu 4. U scenariju 2 kao i u scenariju 1, na grafikonu vidljivo je smanjenje ukupnog vremena putovanja primjenom algoritma u svih deset simulacija. Bez algoritma vozilo žurne službe prosječno je putovalo 487 sekundi kroz 10 simulacija. Primjenom algoritma bez povratka vremena, vozilo žurne službe je prosječno putovalo 452 sekundi. Primjenom dodatnog algoritma za povratak vremena bez normiranja, vozilo žurne službe prosječno je putovalo 451 sekundi. Primjenom dodatnog normiranja algoritma za povratak vremena, vozilo žurne službe je putovalo 451 sekundi. Prosječno smanjenje ukupnog vremena putovanja u odnosu na prolazak vozila žurne službe bez algoritma iznosi 40 sekundi.



Grafikon 4: Ukupno vrijeme putovanja vozila žurne službe za četvrti scenarij

Zbog velikih oscilacija među simulacijama potrebno je izračunati prosječne podatke te nad njima provesti analizu. Prosječni podaci za prosječno vrijeme putovanja vozila žurne službe prikazano je na grafikonu 5. Prema grafikonu 5 vidljivo je smanjenje vremena putovanja vozila žurne službe u svim scenarijima. Primjena algoritma s povratkom oduzetog vremena radi blago poboljšanje u svim scenarijima osim u scenariju 1. Zbog jednostavnosti rute i stohastičke prirode najbolji rezultati su ostvareni u scenariju 2. Korištenjem algoritma za dodjelu prioriteta ostvareno je smanjenje vremena putovanja vozila žurne službe za 10,83%, dok uz algoritam povratka vremena s normiranjem 13,83%. Također, vidljivo je da algoritam dodjele prioriteta uz algoritam povratka vremena bez normiranja daje neznatno bolje prosječne rezultate nego uz algoritam s normiranjem, u iznosu od 14,12%.



Grafikon 5: Prosječno vrijeme putovanja vozila žurne službe

7 Zaključak

Povećanje broja vozila u gradskim sredinama izravno utječe na kvalitetu i sigurnost gradskog prometnog sustava. Zbog nemogućnosti fizičkog širenja prometne infrastrukture za poboljšanje razine uslužnosti potrebno je pribjeći različitim prometnim mjerama i rješenjima. Primjenom ITS rješenja poput adaptivnog upravljanja semaforiziranim raskrižjima uvelike se može pomoći pri poboljšanju razine uslužnosti i sigurnosti u prometu urbanih sredina. U ovom radu je predložen i implementiran algoritam dodjele prioriteta zasnovan na praćenju položaja vozila i mjerenju reda čekanja na raskrižju. Algoritam na osnovu procjene vremena dolaska žurnog vozila mijenja trajanje faza signalnog plana s ciljem omogućavanja brzog i sigurnog prolaska žurnog vozila kroz raskrižje. Zbog dodjele bezuvjetnog prioriteta vozilu žurne službe dolazi do negativnih utjecaja na ostatak prometne mreže. Kako bi se smanjio taj negativan učinak dodatno je predložen i implementiran algoritam za povratak oduzetog vremena. Navedeni algoritmi su implementirani u programskom paketu MATLAB povezan COM sučeljem s mikroskopskim prometnim simulatorom PTV VISSIM radi njihove simulacijske provjere.

Analiza rada implementiranih algoritama nad izrađenom prometnom mrežom pokazuje poboljšanje u svim simuliranim scenarijima. Najbolje prosječno poboljšanje se očituje u scenariju s povećanjem prometne potražnje gdje je postignuto smanjenje trajanja putovanja vozila žurne službe za 74 sekunde, odnosno 14,12%. Ovakvo poboljšanje pridonosi većoj sigurnosti sudionika u prometu, smanjenju troškova poreznih obveznika i vlasti, te omogućuje brz odziv žurnih službi što doprinosi većoj javnoj sigurnosti i spašava živote. Nastavak istraživanja vidi se u implementaciji algoritma strojnog učenja i proširenje prometne mreže za optimizaciju postavljenih parametara dodjele prioriteta.

Literatura

- [1] Bošnjak, I. *Inteligentni transportni sustavi 1*. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2006.
- [2] Skočibušić B. M. *Ekonomika prometa*. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2011.
- [3] Kapusta, B., Miletić, M. Analiza utjecaja adaptivnog upravljanja signalnim planovima semaforiziranog raskrižja na vrijeme putovanja vozila žurnih službi. Rektorova nagrada, Sveučilište u Zagrebu, Zagreb, 2017.
- [4] F. Paniati Jeffrey and Marilena Amoni. Traffic signal preemption for emergency vehicles, January 2006.
- [5] Vujić, M. *Sustav dinamičkih prioriteta za vozila javnog gradskog prijevoza u automatskom upravljanju prometom*. Zagreb. Doktorska disertacija, Fakultet Prometnih Znanosti, Sveučilište u Zagrebu, 2013.
- [6] VWK. Ngan. A comprehensive strategy for transit signal priority. Master's thesis, University of British Columbia, Vancouver, Canada, Listopad 2002.
- [7] Furth P.G., Muller T.H.J. Conditional bus priority at signalized intersections: Better service quality with less traffic disruption, 2000.
- [8] Gartner, N.H. Development and implementation of an adaptive control strategy in traffic signal network: The virtual-fixed-cycle approach, 2002.
- [9] W. Ekeila, T. Sayed, and M. El Esawey. Development of dynamic transit signal priority strategy, transportation. *Transportation Research Record: Journal of the Transportation Research Board*, 2111:1–9, 2009.

- [10] D. Roegel. Simple algorithms for preemptive traffic control, and an appraisal of their quality. Research Report inria-00000658, INRIA; French Institute for Research in Computer Science and Automation, France, 2005.
- [11] Peter Koonce, Lee Rodegerdts, Kevin Lee, Shaun Quayle, Scott Beaird, Cade Braud, Jim Bonneson, Phil Tarnoff, Tom Urbanik. Traffic Signal Timing Manual. Federal Highway Administration, Turner-Fairbank Highway Research Center, 6300 Georgetown Pike, 2006.
- [12] Traffic design manual. Traffic Operations Division, Traffic Engineering Office, 2016.
- [13] PTV VISSIM. <http://vision-traffic.ptvgroup.com/en-us/products/ptv-vissim/>, pristupljeno: srpanj 2017.
- [14] Kathleen L. Hancock Raj K. Kamalanathsharama. Congestion-based emergency vehicle preemption, 2009.
- [15] Bryan Higgs, Montasir M. Abbas, Alejandra Medina. Analysis of the wiedemann car following model over different speeds using naturalistic data. 2011.
- [16] Buntić M. Ivanjko E., Gregurić M. Uvod u Matlab. predavanja, Fakultet Prometnih Znanosti, Sveučilište u Zagrebu, 2011.
- [17] Tomislav Petković. Kratke upute za korištenje MATLAB-a. predavanja, Fakultet elektrotehnike i računalstva, Sveučilište u Zagrebu, travanj 2005.
- [18] Daniel T. Valentine Brian H. Hahn. Essential matlab for engineers and scientists. Elsevier Ltd., 2007.
- [19] Stefan Wedin. Microsoft's Component Object Model (COM). Department of Computer Engineering, Malardalens Hogskola, 2000.
- [20] Soldo, T. Distribuirano objektno programiranje - COM. predavanja, Visoka škola za informacijske tehnologije, Zagreb, 2016.
- [21] Box, D., Kindel, C., Booch, G. Essential COM. Addison-Wesley Professional, 1998.

- [22] Kapusta, B., Miletić, M., Ivanjko, E., Vujić, M. Preemptive Traffic Light Control based on Vehicle Tracking and Queue Lengths. Prihvaćeno za prezentaciju na međunarodnoj znanstvenoj konferenciji ELMAR2017, 2017.

Popis slika

| | | |
|----|---|----|
| 1 | Grafički prikaz pasivne tehnike razdvajanja faze [5] | 7 |
| 2 | Grafički prikaz pasivne tehnike razdvajanja faze [5] | 8 |
| 3 | Grafički prikaz pasivne tehnike smanjenja trajanja ciklusa [5] | 8 |
| 4 | Grafički prikaz tehnike ranije početka zelenog svjetla [5] | 10 |
| 5 | Grafički prikaz tehnike umetanja faze za ciljanu skupinu vozila [5] | 11 |
| 6 | Prikaz dijagrama toka algoritma za dodjelu prioriteta prema cjelinama [3] . | 14 |
| 7 | Prikaz dijagrama toka algoritma povratka oduzetog vremena [3] | 16 |
| 8 | Prikaz dvostruke prstenaste strukture NEMA upravljača u osam faza [3] . . | 18 |
| 9 | Prikaz izvođenja simulacije raskrižja u VISSIM-u [3] | 21 |
| 10 | Prikaz sučelja u programskom simulatoru VISSIM | 22 |
| 11 | Prikaz sučelja u programskom paketu MATLAB | 23 |
| 12 | COM veza između klijenta i poslužitelja [20] | 24 |
| 13 | Dijagram slijeda spajanja programskog paketa MATLAB i simulacijske apli- kacije VISSIM | 26 |
| 14 | Prikaz potpisa metode za dodavanje vozila unutar COM pomoći u VISSIM-u | 28 |
| 15 | Metoda izračuna udaljenosti od raskrižja poznavanjem duljine spojnice i položaja na spojnici [3] | 29 |
| 16 | Model raskrižja "Ulica kralja Zvonimira - Harambašićeva ulica" | 31 |
| 17 | Prikaz signalnog plana raskrižja "Ulica kralja Zvonimira - Harambašićeva ulica" u VISSIM-u [3] | 32 |
| 18 | Prikaz smjera dolaska (zeleno) i povratka (crveno) vozila žurne službe: a) Scenarij 1 i 2; b) Scenarij 3 i 4 [3] | 34 |

Popis tablica

| | | |
|---|---|----|
| 1 | Zadano prometno opterećenje u ovisnosti o prometnom scenariju | 34 |
|---|---|----|

Popis grafikona

| | | |
|---|--|----|
| 1 | Ukupno vrijeme putovanja vozila žurne službe za prvi scenarij | 35 |
| 2 | Ukupno vrijeme putovanja vozila žurne službe za drugi scenarij | 36 |
| 3 | Ukupno vrijeme putovanja vozila žurne službe za treći scenarij | 37 |
| 4 | Ukupno vrijeme putovanja vozila žurne službe za četvrti scenarij | 38 |
| 5 | Prosječno vrijeme putovanja vozila žurne službe | 39 |